Automação de Contagem de Pontos de Tiro Esportivo em Ambientes Fechados, uma Abordagem Utilizando Aprendizado de Máquina

Osman Atef Issa[1], **Guilherme Pina Cardim**[1]

[1]Departamento de Computação – Universidade Estadual de Londrina (UEL)
Caixa Postal 10.011 – CEP 86057-970 – Londrina – PR – Brasil

osman@uel.br, gpcardim@uel.br

Abstract. *The practice of target shooting, both for sporting purposes and for police and military training, has part of it's process the counting of the score to evaluate the participant's performance. When done manually, this task usually presents to be very laborous, for this purpose this work proposes a solution that combines computer vision with machine learning to automate the task of score counting.*

Resumo. *A prática de tiro ao alvo, tanto para a finalidade esportiva quanto para o treinamento policial e militar, tem como parte de seu processo a contagem da pontuação para avaliar o desempenho do participante. Quando feita manualmente essa tarefa costuma ser bastante trabalhosa, visto isso, esse trabalho propõe uma solução que combina visão computacional com aprendizado de máquina para automatizar a tarefa de contagem da pontuação.*

1. Introdução

Um local de tiro ao alvo é uma facilidade ou local projetado especificamente para treino, prática de competições e até de qualificação para o porte de armas de fogo. Normalmente é realizado em ambientes fechados, aonde o desempenho dos participantes é determinado por alguma forma de pontuação. A pontuação é efetuada de acordo com a posição dos projéteis encontrados no alvo. O processo de contagem é frequentemente realizado de forma manual, um processo trabalhoso e que consome uma boa quantidade de tempo. Diversas tentativas de automatizar o processo, apresentadas a seguir, vêm surgindo e apresentando diferentes técnicas de processamento acústico ou de imagens com altos índices de acerto.

Os métodos baseados em acústica [1] são atualmente usados por muitos países como uma forma automática de contagem de pontuação, que faz uso de um par de sensores vetoriais por cada alvo para identificar um acerto e/ou erro pelo meio da amplitude de onda do impacto e as diferenciais do tempo de chegada da onda de impacto entre os dois sensores. Outro sistema semi-automático de pontuação de tiro ao alvo [2] utiliza um circuito fechado de sistema televisivo e um computador. O observador marca o ponto de impacto exibido no monitor, enviando assim a informação do ponto de impacto ao computador que faz o processamento da pontuação. Os sistemas de pontuação baseados em acústica envolvem circuitos complexos e o posicionamento de sensores na frente do alvo. Além disso é uma tecnologia de alto custo financeiro. Por outro lado, o sistema semi-automático televisivo de contagem de pontos pode induzir erro humano, tornando-o menos recomendado que a implementação acústica.

Vários trabalhos vêm propondo o uso da visão computacional como uma alternativa mais barata. A publicação de Atif Mansoor [3] faz uso de morfologia matemática e limiarização por histerese. Jacek Rudzinski e Marcin Luckner [4] apresentam um mecanismo baseado na transformada de Hough para a detecção dos acertos. Ruswono Aryan [5] apresenta uma solução utilizando máquinas de vetores de suporte para a segmentação dos buracos presentes nos alvos.

Este projeto tomará como base a solução de Cardim e Dias [6] que propõe um sistema automático de baixo custo computacional para a contagem de pontos de alvos de dois tipos: de círculos concêntricos como mostrado na Figura 1 e o de elipses concêntricas como apresentado na Figura 2. A solução que se destaca pelo seu extenso uso da morfologia matemática, teve resultados de 97% de acerto na detecção dos tiros e 100% de acerto na contagem da pontuação no caso dos tiros corretamente detectados. O trabalho possui por objetivo aplicar técnicas de aprendizado de máquina e processamento digital de imagens para realizar automaticamente a detecção e o cálculo da pontuação obtida por um atirador.

Figura 1. Alvo baseado em círculos concêntricos

Figura 2. Alvo baseado em elipses concêntricas

2. Fundamentação Teórico-Metodológica

Aprendizado de máquina é um ramo da inteligência artificial e da ciência da computação que se concentra no uso de dados e algoritmos para imitar a maneira como os humanos aprendem, melhorando gradualmente sua precisão. Nos algoritmos de aprendizado de máquina existe a noção de dados de treino, que é uma base de dados utilizada pelo modelo de aprendizado. São usados para ensinar os modelos de predição como extrair características que são relevantes aos objetivos da pesquisa.

Neste trabalho serão abordados alguns dos algoritmos de aprendizado de máquina já implementados pela biblioteca de visão computacional OpenCV desenvolvida na linguagem de programação C++. Os algoritmos são o classificador de Bayes, k-vizinhos mais próximos, máquinas de suporte de vetores, árvores de decisão, impulsionamento, redes neurais e regressão logística. O objetivo do estudo é de encontrar o algoritmo de aprendizado de máquina mais apropriado para melhorar o cálculo automático da pontuação de tiro ao alvo.

2.1. Classificador de Bayes

Classificadores de Bayes pertencem à classe de classificadores na qual é empregado o conceito de probabilidade. Esta técnica é baseada no teorema de Bayes [7]. Os classificadores de Bayes requerem um número de parâmetros de variáveis lineares que são altamente escaláveis para um problema de aprendizado. O treinamento de probabilidade máxima é baseado na mensuração de uma expressão de forma fechada.

Os classificadores de Bayes são utilizados na criação de modelos classificadores, que alocam rótulos de classes para definir instâncias de problemas, representados como vetores de valores característicos, aonde os rótulos de classes são tomados de um conjunto finito. Os Classificadores de Bayes assumem que o valor de uma característica particular é independente do valor dado de qualquer outra característica de uma classe dada.

2.2. Árvores de Decisão

Árvores de decisão [8] são uma forma de modelar decisões e seus resultados, mapeando as decisões em uma estrutura de ramificação. São utilizadas para calcular o potencial sucesso de diferentes combinações de decisões realizadas para atingir um objetivo específico. O conceito da árvore de decisão existe antes do aprendizado de máquina ter sido proposto, afinal pode ser usado para modelar manualmente operações de decisão como um fluxograma. São bastantemente ensinados e empregados em negócios, economia e operação de gerenciamento de setores para analisar as tomadas de decisão organizacionais.

As árvores de decisão são uma forma de modelagem preditiva, auxiliando no mapeamento das diferentes decisões e soluções de um resultado. Uma árvore de decisão é formada por vários nós. O nó raiz ó o início da árvore de decisão, que é normalmente toda a base de dados dentro do aprendizado de máquina. Os nós folhas são o ponto final de cada ramificação, ou seja, a saída final de uma série de decisões. Com árvores de decisão em aprendizado de máquina, as características do dado são os nós internos e a saída é o nó folha.

As árvores de decisão são uma abordagem de aprendizado de máquina supervisionado, uma técnica que faz uso de entradas rotuladas e bases de dados de saída para treinar

os modelos. A abordagem é geralmente utilizada na solução de problemas de classificação, fazendo uso de um modelo para categorizar ou classificar um objeto. As árvores de decisão são também utilizados em problemas de regressão, uma abordagem utilizada em analítica preditiva para prever saídas de dados não previstos.

2.3. K-Vizinhos Mais Próximos

O algoritmo dos k-vizinhos mais próximos [9] é um classificador de aprendizado de máquina do tipo supervisionado, que faz uso de aproximação para realizar classificações ou predições sobre o agrupamento de um ponto de dados individual. Por sua natureza é um algoritmo de classificação, trabalhando com a suposição de que os pontos similares podem serem encontrados um próximo ao outro.

Em problemas de classificação, um rótulo de classe é designado com base no voto majoritário, isto é, o rótulo que é mais frequentemente representado ao redor de um certo ponto dado é usado. Enquanto isso é tecnicamente considerado uma "votação em pluralidade", o termo "votação majoritária" costuma ser mais encontrado na literatura. A distinção entre essas terminologias é que o "voto majoritário" requer tecnicamente uma maioria maior que 50%, que funciona primariamente quando existem apenas duas categorias. Para casos de múltiplas classes, isto é quatro ou mais, não é necessário ter 50% dos votos para obter uma conclusão sobre a classe, podendo designar um rótulo de classe com votação maior que 25%.

2.4. Máquinas de supporte de vetores

Originalmente, as máquinas de supporte de vetores (SVM do inglês de Support Vector Machines) [10] foi uma técnica para construir classificadores binários ótimos. Futuramente a mesma foi estendida para problemas de regressão e agrupamento. SVMs são casos parciais dos métodos baseados em Kernel. Ela mapeia os vetores de características para um espaço de dimensão maior utilizando uma função de Kernel e constrói uma função linear discriminatória ótima neste espaço ou um hiperplano ótimo que se encaixa nos dados treinados. No caso da SVM, o Kernel não é explicitamente definido. Ao invés disso, a distância entre quaisquer dois pontos no hiperespaço deve ser definido.

A solução de uma SVM é ótima, o que significa que a margem entre o hiperplano de separação e os vetores de características de ambas as classes, no caso do classificador binário, é máxima. O vetor de características que são os mais próximos ao hiperplano são conhecidos como vetores de suporte, que significa que a posição de outros vetores não afetam o hiperplano (a função decisiva).

2.5. Impulsionamento

Em termos de aprendizado de máquina, impulsionamento [11] é um método de agrupamento que combina um conjunto de agentes aprendedores em um agente mais forte para minimizar erros de treinamento. No impulsionamento, uma amostra aleatória de dados é selecionada, montada em um modelo e treinada sequencialmente, isto é, cada modelo tenta compensar as fraquezas de seu antecessor. Para cada iteração, as regras fracas de cada classificador são combinadas para formar uma regra mais forte de predição.

2.6. Regressão Logística

Regressão Logística [12], também conhecido como o modelo logit, é um modelo estatístico que é frequentemente usado para análises preditivas e classificatórias. A regressão logística estima a probabilidade de um evento ocorrer, baseado em uma base de dados de variáveis independentes. Pela saída ser uma probabilidade, a variável dependente é limitada entre 0 e 1. Na regressão logística, a transformação de logit é aplicada nas chances, isto é, a probabilidade de sucesso dividida pela chance de erro. Esse processo também é conhecido como o logaritmo das chances, dado pelo razão de chances, pode ser representado pelas Fórmulas 1 e 2:

$$logit(p_i) = \frac{1}{1 + e^{-p_i}} \tag{1}$$

$$ln(\frac{p_i}{1 - p_i}) = \beta_0 + \beta_1 \times x_1 + ... + \beta_k \times k_k \tag{2}$$

Nesse tipo de regressão, $logit(p_i)$ é a variável de resposta e x é a variável independente. O parâmetro β ou o coeficiente neste modelo é estimado com a estimativa de verossimilhança máxima. Esse método testa valores diferentes para β através de diversas iterações para encontrar a melhor combinação de razão de chances. Todas as iterações produzem uma função de logaritmo de verossimilhança, e a regressão logística busca maximizar essa função para encontrar a melhor estimativa de parâmetro. Quando o coeficiente ótimo é encontrado, as probabilidades condicionais para cada observação podem serem calculadas e somadas, produzindo um probabilidade preditiva.

2.7. Redes Neurais

Redes neurais [13] (RNs), também conhecidas como redes neurais artificiais ou redes neurais simuladas, são um subconjunto do aprendizado de máquina e estão no coração dos algoritmos de aprendizagem profunda. Seu nome e estrutura são inspirados no cérebro humano na forma que os neurônios biológicos sinalizam de um para o outro.

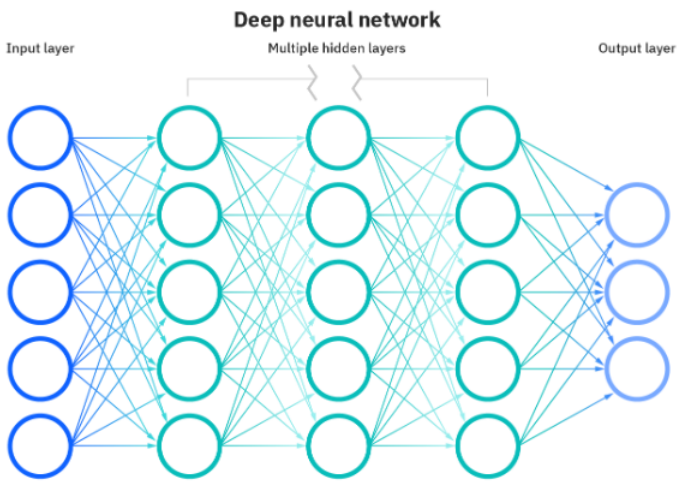

Figura 3. Esboço de uma rede neural, as camadas de entrada se encontram no extremo esquerdo e as de saída no extremo direito

Redes neurais artificias são compostas por camadas de nós, contendo uma camada de entrada, uma ou mais camadas escondidas e uma camada de saída. Cada camada, conhecida como neurônio artificial, se conecta com outro e tem peso e limiar associados. Se a saída de qualquer nó individual estiver acima do limiar especificado, este nó é então ativado, enviando dado para a próxima camada da rede. Caso contrário, nenhum dado é passado para a próxima camada da rede.

As redes neurais dependem de dados de treinamento para aprender e melhorar sua precisão ao longo do tempo. No entanto, uma vez que esses algoritmos de aprendizado têm sua precisão calibrada, se tornam ferramentas poderosas em ciência da computação e inteligência artificial, permitindo classificar e agrupar dados em alta velocidade. Tarefas de reconhecimento de fala ou reconhecimento de imagem que levam horas para serem identificadas por especialistas humanos são drasticamente reduzidas para segundos. Uma das redes neurais mais conhecidas é o algoritmo de busca da empresa Google [14].

3. Objetivos

O objetivo do trabalho é de expandir a tese apresentada por Cardim [6] que faz extenso uso da morfologia matemática em diversas fases do processamento. Com a utilização de um ou mais algoritmos de aprendizado de máquina, espera-se melhorar a contagem da pontuação que no momento tem precisão de 97% para a detecção dos buracos de tiros e 100% para a contagem da pontuação nos casos de detecção verdadeira dos buracos de tiros.

4. Metodologia

O desenvolvimento da tese deve ocorrer em quatro fases. Primeiramente será efetuado um estudo sobre os conceitos de aprendizado de máquina, visando encontrar o algoritmo mais apropriado para esse projeto. Em segundo momento, o algoritmo escolhido será implementado para complementar a solução de Cardim. A terceira fase de testes será de coleta de resultados estatísticos de desempenho do algoritmo implementado, a amostra será dada por uma base de dados de imagens similares às Figuras 1 e 2. Finalmente, serão apresentadas conclusões baseadas nos dados obtidos pela terceira fase.

5. Cronograma de Execução

Seguem as atividades que serão realizadas, e seu cronograma dado na tabela 1:

1. Estudo dos conceitos de aprendizado de máquina e escolha do algoritmo apropriado
2. Implementação do algoritmo escolhido na atividade 1
3. Aplicação da tese na amostra e coleta de estatísticas
4. Escrita da tese apresentando os resultados

	ago	set	out	nov	dez	jan	fev	mar	abr	jun
Atividade 1	x	x								
Atividade 2			x	x	x					
Atividade 3						x	x	x		
Atividade 4						x	x	x	x	x

Tabela 1. Cronograma de Execução

Londrina, 12 de setembro de 2022.

Aluno

Orientador

Referências

[1] S. R. Hsieh A. Sean, C. Sanctuary. Remote strafe scoring system, united states patent 4813877, 1989.

[2] Homer B Ripley. Range scoring system, united states patent 3793481, 1974.

[3] Atif Mansoor. Computer vision based automatic scoring of shooting targets, 2008.

[4] Marcin Luckner Jacek Rudzinski. Automatic scoring of shooting targets with tournament precision, 2012.

[5] Peb Ruswono Aryan. Vision based automatic target scoring system for mobile shooting range, 2012.

[6] Maurício Araújo Dias Guilherme Pina Cardim. Mathematical morphology applied to automation of indoor shooting ranges, 2014.

[7] Stuart Russell Peter Norvig. Inteligência artificial, uma abordagem moderna, capítulo 14, 2013.

[8] Stuart Russell Peter Norvig. Inteligência artificial, uma abordagem moderna, seção 18.7, 2013.

[9] Zhongheng Zhang. Introduction to machine learning: k-nearest neighbors, 2016.

[10] Stuart Russell Peter Norvig. Inteligência artificial, uma abordagem moderna, seção 18.3, 2013.

[11] Robert E. Schapire. The boosting approach to machine learning an overview, 2001.

[12] Lucila Ohno-Machado Stephan Dreiseitla. Logistic regression and artificial neural network classification models: a methodology review, 2003.

[13] Stuart Russell Peter Norvig. Inteligência artificial, uma abordagem moderna, seção 18.7, 2013.

[14] Google LLC, 1998. `http://www.google.com`, Acessado em 2020/15/09.